开篇词 | 阅读源码，逐渐成了职业进阶道路上的“必选项”

2020-04-13 胡夕

讲述：胡夕
时长 13:31 大小 12.40M

你好，我是胡夕，友信金服商业智能部总监，同时也是 Apache Kafka 社区的一名代码贡献者。目前，我在社区的贡献排行榜上排在第 21 位，应该算是国内比较活跃的社区参与者了。

2019 年，我在极客时间开设了我的第一个专栏《Kafka 核心技术与实战》，想要帮助 Kafka 用户掌握 Kafka 核心设计原理及实战应用技术。时隔一年，我又带来了一个源码专栏。在这个专栏中，我会带你深入到 Kafka 核心源码，详细分析和讲述那些源码背后的架构思想和编程理念。同时，我还会针对一些棘手问题，给出源码级的解决思路。

为什么要读源码？

谈到源码分析，特别是 Apache Kafka 这类消息引擎的源码，你可能会说：“我都已经在使用它了，也算是也比较熟练了，何必还要再花费时间去阅读源码呢？”

当然了，一些非 Kafka 使用者也会说：“我不用 Kafka，读源码对我有什么用呢？”

其实，在没有阅读源码之前，我也是这么想的。但是，后来在生产环境上碰到的一件事，彻底改变了我的想法。

我们知道，Kafka Broker 端有个 log.retention.bytes 参数，官网的描述是：它指定了留存日志的最大值。有了这个参数的“帮忙”，我们信誓旦旦地向领导保证，不会过多占用公司原本就很紧张的物理磁盘资源。但是，最终实际占用的磁盘空间却远远超出了这个最大值。

我们查遍了各种资料，却始终找不到问题的根因，当时，我就想，只能读源码碰碰运气了。结果，源码非常清楚地说明了，这个参数是不是能起作用和日志段大小息息相关。知道了这一点，问题就迎刃而解了。

这时，我才意识到，很多棘手的问题都要借助源码才能解决。

除此之外，我还发现，在很多互联网公司资深技术岗位的招聘要求上，“读过至少一种开源框架的源码”赫然在列。这也就意味着，**阅读源码正在从“加分项”向“必选项”转变，掌握优秀的框架代码实现从 NICE-TO-DO 变成了 MUST-DO**。

那，为什么读源码逐渐成为了必选项？它究竟有什么作用呢？下面我结合我自己的经历，和你说说读源码的几点收获。

1. 可以帮助你更深刻地理解内部设计原理，提升你的系统架构能力和代码功力。

作为一款优秀的消息引擎，Kafka 的架构设计有很多为人称道的地方，掌握了这些原理将极大地提升我们自身的系统架构能力和代码功力。

当然了，即使你不使用 Kafka，也可以借鉴其优秀的设计理念，提升你在其他框架上的系统架构能力。

你可能会问，官网文档也有相应的阐述啊，我单纯阅读文档不就够了吗？

实际上，我一直认为社区官方文档的内容有很大的提升空间，**Kafka 有许多很棒的设计理念和特性，在文档中并未得到充分的阐述。**

我简单举个例子。Kafka 中有个非常重要的概念：**当前日志段（Active Segment）**。Kafka 的很多组件（比如 LogCleaner）是区别对待当前日志段和非当前日志段的。但是，Kafka 官网上几乎完全没有提过它。

所以你看，单纯依赖官网文档的话，肯定是无法深入了解 Kafka 的。

2. 可以帮你快速定位问题并制定调优方案，减少解决问题的时间成本。

很多人认为，阅读源码需要花费很多时间，不值得。这是一个非常大的误区。

实际上，你掌握的源码知识可以很好地指导你日后的实践，帮助你快速地定位问题的原因，迅速找到相应的解决方案。最重要的是，**如果你对源码了然于心，你会很清楚线上环境的潜在问题，提前避“坑”。在解决问题时，阅读源码其实是事半功倍的“捷径”**。

如果用时间成本来考量的话，你可以把阅读源码的时间分摊到后续解决各种问题的时间上，你会发现，这本质上是一件划算的事情。

3. 你还能参加 Kafka 开源社区，成为一名代码贡献者（Contributor）。

在社区中，你能够和全世界的 Kafka 源码贡献者协同工作，彼此分享交流，想想就是一件很有意思的事情。特别是当你的代码被社区采纳之后，全世界的 Kafka 使用者都会使用你写的代码。这简直太让人兴奋了，不是吗？

总而言之，**阅读源码的好处真的很多，既能精进代码功力，又能锤炼架构技巧，还能高效地解决实际问题，有百利而无一害。**

如何用最短的时间掌握最核心的源码？

Kafka 代码有 50 多万行，如果我们直接冲下场开始读，一定会“丈二和尚摸不着头脑”。

毕竟，面对这么多代码，通读一遍的效率显然并不高。为了避免从入门到放弃，我们要用最高效的方式阅读最核心的源码。

通常来说，阅读大型项目的源码无外乎两种方法。

自上而下（Top-Down）：从最顶层或最外层的代码一步步深入。通俗地说，就是从 main 函数开始阅读，逐渐向下层层深入，直到抵达最底层代码。这个方法的好处在于，你遍历的是完整的顶层功能路径，这对于你了解各个功能的整体流程极有帮助。

自下而上（Bottom-Up）：跟自上而下相反，是指先独立地阅读和搞懂每个组件的代码和实现机制，然后不断向上延展，并最终把它们组装起来。该方法不是沿着功能的维度向上溯源的，相反地，它更有助于你掌握底层的基础组件代码。

这两种方法各有千秋，不过，在学习 Kafka 源码的过程中，我发现，将两者结合的方法其实是最高效的，即先弄明白最细小单位组件的用途，然后再把它们拼接组合起来，掌握组件组合之后的功能。

具体怎么做呢？首先，你要确认最小单位的组件。我主要是看 Kafka 源码中的包结构（package structure），比如 controller、log、server 等，这些包基本上就是按照组件来划分的。我给这些组件确定的优先级顺序是“log–>network–>controller–>server–>coordinator–>……”，毕竟，后面的组件会频繁地调用前面的组件。

等你清楚地了解了单个组件的源码结构，就可以试着切换成自上而下的方法，即从一个大的功能点入手，再逐步深入到各个底层组件的源码。得益于前面的积累，你会对下沉过程中碰到的各层基础代码非常熟悉，这会带给你很大的成就感。比起单纯使用自上而下或自下而上的方法，这套混合方法兼具了两者的优点。

关于如何选择大的功能点，我建议你从 Kafka 的命令行工具开始这种串联学习，搞明白这个工具的每一步都是怎么实现的，并且在向下钻取的过程中不断复习单个组件的原理，同时把这些组件结合在一起。

随着一遍遍地重复这个过程，你会更清楚各个组件间的交互逻辑，成为一个掌握源码的高手！

知道了方法以后，我们就可以开始 Kafka 源码的学习了。在深入细节之前，我们先来看下 Kafka 的源码全景图，找到核心的源码。

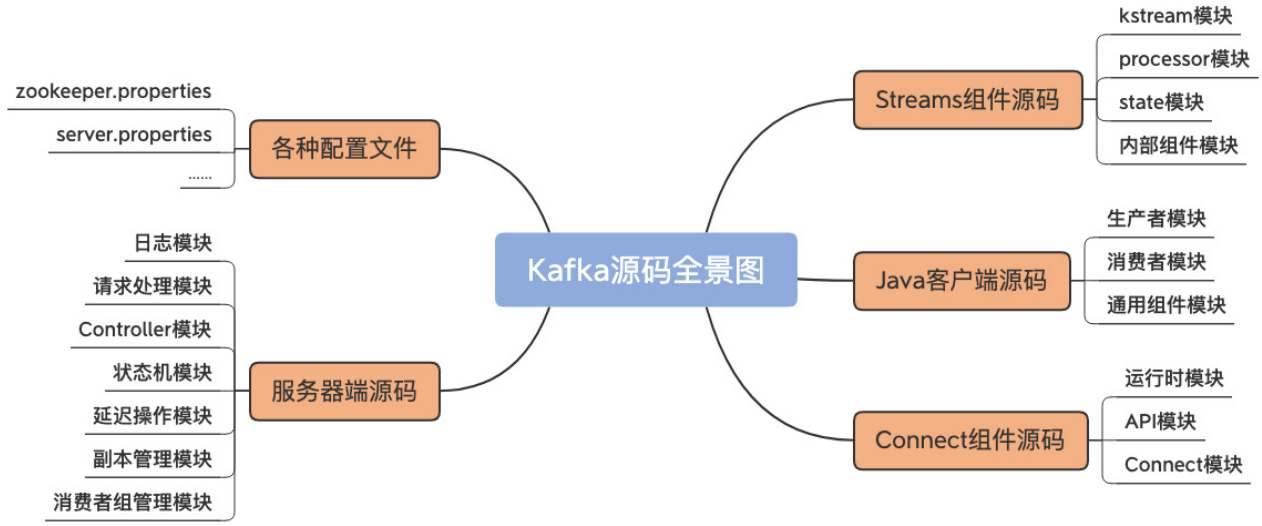

极客时间

从功能上讲，Kafka 源码分为四大模块。

服务器端源码：实现 Kafka 架构和各类优秀特性的基础。

Java 客户端源码：定义了与 Broker 端的交互机制，以及通用的 Broker 端组件支撑代码。

Connect 源码：用于实现 Kafka 与外部系统的高性能数据传输。

Streams 源码：用于实现实时的流处理功能。

可以看到，服务器端源码是理解 Kafka 底层架构特别是系统运行原理的基础，其他三个模块的源码都对它有着强烈的依赖。因此，**Kafka 最最精华的代码，当属服务器端代码无疑！**我们学习这部分代码的性价比是最高的。

专栏是如何设计的？

那，我们就抓紧开始吧。在这个专栏里，我基于自己对服务器端源码结构的理解，特意为你精选了下面这些源码。

这些源码全都是极具价值的组件，也是很多实际线上问题的“高发重灾区”。比如，Kafka 日志段的代码逻辑就是很多线上异常的“始作俑者”。掌握这些源码能够大大地缩短你定位问题花费的时间。

我把服务器端源码按照功能划分了 7 个模块，每个模块会进一步划开多个子部分，详细地给出各个组件级的源码分析。你可以看下这张思维导图的重点介绍。

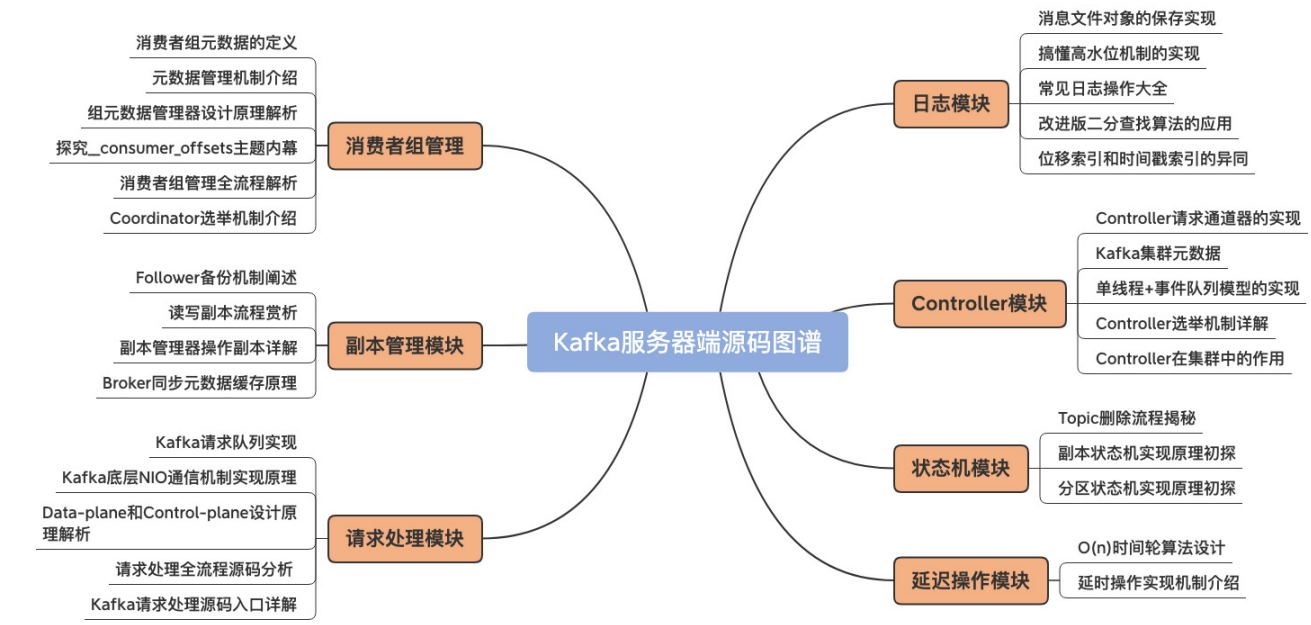

极客时间

丰富的流程图 + 细粒度讲解

在读源码时，我们最常犯两种错误，一种是直接深入最底层的一行行源码之中，陷入细枝末节；另一种是过于粗粒度地学习，学了跟没学没有什么区别。

为了帮助你高效地学习，我摒弃了贪多求全的源码讲解方式，而是采用“流程图 + 代码注释”相结合的方式，对重点内容进行细粒度讲解，还会结合我的实战经验，给你划重点。

在阅读源码之前，你可以借助图片对各个方法的实现逻辑有个大致的了解。对于重点内容，我会用详细的注释形式帮助你理解。同时，我还绘制了思维导图，帮你总结回顾。

真实的案例讲解，解决你的实战问题

很多人虽然也读源码，却不懂源码可以应用到什么场景、解决什么问题。事实上，我在生产环境中碰到的很多问题，都是没办法单纯依赖官方文档或搜索引擎顺利解决的。只有阅读源码，切实掌握了实现原理，才能找到解决方案。

为了帮你学以致用，我会在专栏里给你分享大量的真实案例，既帮助你提前规避陷阱，也帮你积累一些常见问题的解决方案，有一些甚至是不见诸于文档的“武林秘籍”。

传递社区的最新发展动向

这是专栏最有意思的一部分。我们学习的 Kafka 源码每天都在不断地演进着，要想玩转 Kafka，就必须要知道社区未来的更新计划以及重大功能改进。

我会针对一些具体的主题，给你分享最新的动态资讯。我希望展现在你面前的不再是一行行冰冷的代码，而是一个生动活泼的社区形象，让你真正有参与到社区的感觉。不要小看这种感觉，有的时候，它甚至是支撑你走完源码学习之路的最强大动力。

课外拓展

除此之外，我还会跟你分享一些延伸内容。比如成为 Apache Kafka 社区的代码贡献者的具体方法、实用的学习资料、经典的面试题讲解等，希望你也不要错过这部分的内容。

06 请求通道：如何实现 Kafka 请求队列?

07 SocketServer (上)：Kafka 到底是怎么应用 NIO 实现网络通信的?

08 SocketServer (中)：请求还要区分优先级?

09 SocketServer (下)：请求处理全流程源码分析

10 KafkaApis：Kafka 最重要的源码入口，没有之一

Controller 模块

11 Controller 元数据：Controller 都保存有哪些东西?有几种状态?

12 ControllerChannelManager：Controller 如何管理请求发送?

13 ControllerEventManager：变身单线程后的 Controller 如何处理事件?

14 Controller 选举是怎么实现的?

15 如何理解 Controller 在 Kafka 集群中的作用?

■ 期中总结 | 三个典型问题答疑

状态机模块

16 TopicDeletionManager：Topic 是怎么被删除的?

17 ReplicaStateMachine：揭秘副本状态机实现原理

18 PartitionStateMachine：分区状态转换如何实现?

延迟操作模块

19 TimingWheel：探究 Kafka 定时器背后的高效时间轮算法

20 DelayedOperation：Broker 是怎么延时处理请求的?

副本管理模块

21 ReplicaFetcherThread：Follower 拉取 Leader 消息是如何实现的?

22 ReplicaManager（上）：副本管理器是如何读写副本的?

23 ReplicaManager（下）：副本管理器是如何管理副本的?

24 MetadataCache：Broker 是怎么异步更新元数据缓存的?

消费者组管理模块

25 消费者组元数据（上）：消费者组都有哪些元数据?

26 消费者组元数据（下）：Kafka 如何管理这些元数据?

27 GroupMetadataManager（上）：组元数据管理器是个什么东西?

28 GroupMetadataManager（下）：探究 __consumer_offsets 主题的管理内幕

29 GroupCoordinator（上）：消费者组管理全流程解析

30 GroupCoordinator（下）：当前 Coordinator 卸任了怎么办?

■ 期末测试 | 一套习题，测出你的掌握程度

特别放送

特别放送（一）| 经典的 Kafka 学习资料有哪些?

特别放送（二）| 一篇文章带你了解参与开源社区的全部流程
特别放送（三）| 如何充分利用你的 24 小时？
特别放送（四）| Kafka 面试题 Top 30 详细解析
特别放送（五）| Kafka 社区的重磅功能：移除 ZooKeeper 依赖
结束语 | 源码学习，我们才刚上路呢

最后，**我还想再和你说说 Scala 语言的问题**。毕竟，我们将要一起学习的 Broker 端源码是完全基于 Scala 的。

不过，这部分源码并没有用到 Scala 多少高大上的语法特性。如果你有 Java 语言基础，就更不用担心语言的问题了，因为它们有很多特性非常相似。

即使你不熟悉 Scala 语言也没关系。你不需要完整、系统地学习这门语言，只要能简单了解基本的函数式编程风格，以及它的几个关键特性，比如集合遍历、模式匹配等，就足够了。

当然了，为了不影响你理解专栏内涉及的源码，我会在“导读”这节课里带你深入了解下 Scala 语言。同时，在专栏里遇到 Scala 比较难的语言特性时，我也会和你具体解释。所以，你完全不用担心语言的问题。

好了，现在，我们就正式开启 Apache Kafka 源码分析学习之旅吧。正所谓：“日拱一卒无有尽，功不唐捐终入海。”阅读源码是个“苦差事”，希望你别轻易放弃。毕竟，**掌握了源码，你就走在了很多人的前面**。

最后，我很荣幸能够和你在这里相遇，一起学习交流，也欢迎你给我留言，说说你对 Kafka 源码分析的看法和疑问。

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

下一篇　导读 | 构建Kafka工程和源码阅读环境、Scala语言热身

精选留言 (3)

写留言

Kǎfkā²⁰²⁰
2020-04-13

赞，支持

展开

1

侯永强
2020-04-13

顶礼膜拜

展开

萌错错
2020-04-13

文章写得好，老师的录音也很好，真是赚到啦

展开